

PATENT ABSTRACTS OF JAPAN

(11) Publication number: 07152640 A

(43) Date of publication of application: 16 . 06 . 95

(51) Int. CI

G06F 12/06 G06F 15/163

(21) Application number: 05296300

(22) Date of filing: 26 . 11 . 93

(71) Applicant:

HITACHI LTD

(72) Inventor:

YAMAUCHI MASAHIKO YOSHIZAWA SATOSHI MURAYAMA HIDEKI HAYASHI TAKEHISA

KITO AKIRA

(54) DECENTRALIZED COMMON MEMORY SYSTEM

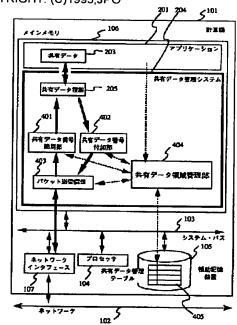
(57) Abstract:

PURPOSE: To decrease the amount of transferred data and the frequency of transfer and to effectively utilize network resources by obtaining information regarding common data such as the timing, etc., of the guarantee for the consistency of common data areas and common data as to the common data that application software uses as if one data were shared for the application software.

CONSTITUTION: A common data management system 204 consists of a common data number discrimination part 401, a common data number addition part 402, a packet transmission and reception part 403, and a common data area management part 404, and hold respective constituent elements of a common data management table 405. When the application software 201 declares data (common unit) to be shared and mapping to a memory to the common data area management part 404, the correspondence between the common data and memory is stored in the common data management table 405. A computer which indicates common data modification and a computer which receives the common data modification guarantee the consistency of the common data by using the respective constituent

elements.

COPYRIGHT: (C)1995,JPO



(12) 公開特許公報(A)

(11)特許出願公開番号

特開平7-152640

(43)公開日 平成7年(1995)6月16日

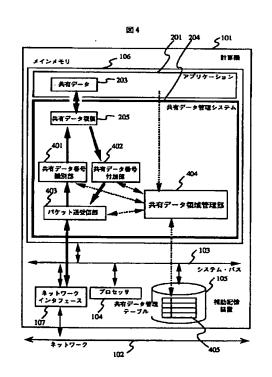
(51) Int.Cl. ⁶ G 0 6 F	12/06 15/163	識別記 530		•	庁内整理番号 9366-5B	FI				技術表示箇所	
					8219-5L	G 0 6 F	15/ 16	3 2 0	M		
						審査請求	未醋求	請求項の数13	OL	(全 19 頁)	
(21)出願番号		特顯平5-2963 00				(71)出願人					
(22)出願日		平成5年(1993)11月26日				(72)発明者	株式会社日立製作所 東京都千代田区神田駿河台四丁目 6 番地 山内 雅彦				
							東京都国分寺市東恋ケ穰1丁目280番地 株式会社日立製作所中央研究所内				
						(72)発明者	東京都国	- 国分寺市東恋ケ智			
						(72)発明者	村山 多				
						(7.4) (h.m.)	東京都国分寺市東恋ケ窪1丁目280番地株式会社日立製作所中央研究所内				
						(74)代理人	开埋士	小川 勝男	ł	最終質に続く	

(54) 【発明の名称】 分散共有メモリ方式

(57)【要約】

【目的】 アブリケーションに対してあたかも一つのデータを共有しているように、アブリケーションが使用する共有データに関して、共有するデータ領域や、共有するデーター貫性保証のタイミング等の共有データに関する情報を得て、データ転送量や転送回数を減らし、ネットワーク資源を有効に活用する。

【構成】 共有データ管理システム204は、共有データ番号識別部401、共有データ番号付加部402、パケット送受信部403、共有データ領域管理部404から構成され、共有データ管理テーブル405の各構成要素を保持する。アブリケーション201が共有するデータ(共有単位)とメモリへの写像を共有データ領域管理部404に対して宣言すると、共有データとメモリとの対応を共有データ管理テーブル405に格納する。共有データ変更を指示した計算機と共有データ変更を受け取る計算機では、上記各構成要素を用いて共有データの一貫性を保証する。



【特許請求の範囲】

【請求項1】複数の計算機がネットワークで接続され、 各計算機のメモリ上に分散したデータを各計算機にて共 有する分散共有メモリ方式において、

計算機のアプリケーションから、各計算機のメモリ上に 分散したデータを任意のアドレス及びサイズよりなる共 有単位で指定し、指定された共有単位にて共有データを 対応付けて管理する共有データ管理手段を上記複数の計 算機の少なくともいずれか一つに設けたことを特徴とす る分散共有メモリ方式。

【請求項2】請求項1に記載の分散共有メモリ方式にお いて、上記共有データの複製を格納する手段を設け、計 算機のアプリケーションは、上記複製に対してRead ✓Writeを行うことを特徴とする分散共有メモリ方 式。

【請求項3】請求項1または2に記載の分散共有メモリ 方式において、各計算機間で共有する領域間の一貫性保 証を、任意のアドレス及びサイズよりなる共有単位で指 定することを特徴とする分散共有メモリ方式。

【請求項4】請求項1または2に記載の分散共有メモリ 20 方式において、各計算機間で共有する領域の任意の部位 を一次元配列への写像として指定し、その一次元配列を 共有単位として指定することを特徴とする分散共有メモ

【請求項5】請求項4に記載の分散共有メモリ方式にお いて、上記一次元配列を格納する領域を、共有単位が指 定された際に、メモリ上で確保することを特徴とする分 散共有メモリ方式。

【請求項6】請求項3に記載の分散共有メモリ方式にお いて、各計算機間で共有する複数の共有単位について、 共有単位間での階層関係を定義し、上記一貫性保証を指 定した共有単位に加え、その下位階層として定義された 共有単位についても一貫性保証を一括して指定すること を特徴とする分散共有メモリ方式。

【請求項7】請求項6に記載の分散共有メモリ方式にお いて、上記一貫性保証を行なう際に、指定された共有単 位の下位階層として定義された共有単位から、任意の下 位階層共有単位を選択して、一貫性保証を一括して行な うことを特徴とする分散共有メモリ方式。

いて、各計算機間でデータを交換する手段として、上記 一貫性保証した共有単位のデータ交換手段と共に、他の データ交換手段を備え、交換するデータのメモリ上での 配置に応じてデータ交換手段を選択することを特徴とす る分散共有メモリ方式。

【請求項9】複数の計算機がネットワークで接続され、 各計算機のメモリ上に分散したデータを各計算機にて共 有する分散共有メモリ方式において、

計算機のアプリケーションから、各計算機のメモリ上に

有単位で指定し、指定された共有単位にて共有データを 対応付けて管理するための共有データ管理テーブルと、 上記共有データ管理テーブルを管理する共有データ領域 管理手段と、

7

他の計算機とのパケットによる上記共有データを送受信 するパケット送受信手段と、

上記パケット送受信手段を介して送信するパケットを生 成するために、共有データを格納するメモリ領域を調 べ、そのメモリ領域に対して共有データ番号を付与する 10 共有データ番号付与手段と、

上記パケット送受信手段を介して受信したパケット中の 共有データ番号を識別し、共有データ番号に対応するメ モリ領域を上記共有データ管理テーブルを用いて調べ、 対応するメモリ領域に共有データを書き込む共有データ 番号識別手段と、

計算機のアプリケーションからRead/Writeを 行うために共有データの複製を格納する手段とを、

上記複数の計算機のうち少なくともいずれか一つに設け たことを特徴とする分散共有メモリ方式。

【請求項10】請求項9に記載の分散共有メモリ方式に おいて、上記共有データ管理テーブルは、共有データ番 号を格納する共有データ番号エントリと、共有データを 管理している計算機かどうかを示す管理ノードフラグエ ントリと、共有データの開始アドレスを示す共有データ アドレスエントリと、共有データの複製の開始アドレス を示す共有データ複製アドレスエントリと、共有データ の大きさを示す共有データサイズエントリと、共有デー タを保持している計算機を示す計算機リストエントリを 有することを特徴とする分散共有メモリ方式。

30 【請求項11】請求項10に記載の分散共有メモリ方式 において、上記共有データ管理テーブルは、アプリケー ションが使用する共有データが連続領域か否かを示す分 割フラグエントリと、幾つの分割されたデータから共有 データが構成されているかを示す共有データ要素数エン トリと、分割されたデータがどのくらいの間隔で並んで いるかを示す共有データオフセットエントリを有すると とを特徴とする分散共有メモリ方式。

【請求項12】請求項11に記載の分散共有メモリ方式 において、上記共有データ管理テーブルは、共有データ 【請求項8】請求項3に記載の分散共有メモリ方式にお 40 が構造体である場合に、構造体の定義を格納する構造体 定義エントリと、構造体のデータ長を格納する構造体サ イズエントリと、複数の共有データに階層関係があるこ とを示す階層要素フラグエントリと、階層要素の共有デ ータ番号を格納する階層要素共有データ番号エントリを 有することを特徴とする分散共有メモリ方式。

> 【請求項13】複数の計算機がネットワークで接続さ れ、各計算機のメモリ上に分散したデータを各計算機に て共有する分散共有メモリ処理方法において、

計算機のアプリケーションから、各計算機のメモリ上に 分散したデータを任意のアドレス及びサイズよりなる共 50 分散したデータを任意のアドレス及びサイズよりなる共

有単位で指定し、

指定された共有単位にて共有データを対応付けて管理す る管理計算機を決定して、上記管理計算機に対して共有 データの使用を要求し、

上記管理計算機では、指定された共有データが使用され ているか否かを確認し、

使用されていない場合には、指定された共有データに関 する情報を上記管理計算機に新規に登録し、

使用されている場合には、新規に共有データの使用を指 定した計算機に関する情報を上記管理計算機に登録し て、その情報を他の計算機に通知し、

共有データの使用を指定した計算機では、各計算機のメ モリ上に分散した共有データを獲得して、共有データの 複製を作成する、

ことを特徴とする分散共有メモリ処理方法。

【発明の詳細な説明】

[0001]

【産業上の利用分野】本発明は、ネットワークで接続さ れた複数の計算機システムで構成されるネットワーク計 算機システムに於いて、物理的に分散配置されたメモリ 20 上のデータを、別計算機上で実行中の複数アプリケーシ ョン間で共有するための分散共有メモリ技術に係わり、 特にネットワーク資源を有効利用し、その結果、分散共 有メモリへのアクセス性能を向上させる分散共有メモリ 方式に関する。

[0002]

【従来の技術】計算機に於いて、計算機内部でアプリケ ーションを実行する仮想的な実体をプロセスと呼ぶ。ブ ロセスを複数生成し、単一CPUの演算資源を一定時間 毎に切り換えて各プロセスに割り当てることで、CPU 30 ている。 台数よりも多いプロセスを並行に動作させることができ る。これを並行処理と呼ぶ。一方、複数のCPUを使用 して、複数のプロセスを同時に動作させる処理を並列処 理と呼ぶ。

【0003】従来、単一CPU構成の計算機に於いて並 行処理を行なう時には、プロセス間でのデータ交換の方 法として共有メモリを使用することができた。これには 例えば、「UNIXシステムコール・プログラミング、 Marc J. Rochkind著、福崎俊博訳、アス キー出版、1987」の299-315頁に示されたシ 40 ステムVの共有メモリがある。

【0004】並行処理では物理的にプロセスが同時に実 行されないために、複数プロセスによって構成されるア ブリケーションの実行性能の向上は望めなかった。そこ で、ネットワーク計算機システムでは、複数の計算機を ネットワークで接続し、複数のCPUを同時に利用して アプリケーションを並列処理することによって、アプリ ケーション実行性能の向上を図る。

【0005】ネットワーク計算機システムに於ける共有

算機のメモリ上に格納されたデータ間の一貫性を保証 し、あたかも一つのデータを共有しているかの様に、ア ブリケーションに見せる必要がある。この技術を分散共 有メモリと呼ぶ。

【0006】仮想記憶機構をページング機構で実現する 計算機では、そのページング機構を拡張して分散共有メ モリを実現することができる。即ち、通常ではメモリア クセスの際、アクセスしようとしたデータがメモリ上に 存在しないとページフォールトを発生し、補助記憶装置 10 からデータが存在するページをメモリ上にロードする。 分散共有メモリでは、ページフォールト発生の際、補助 記憶装置からページを取得する代わりに、他計算機から ネットワークを介して自分の計算機のメモリ上にロード することで実現される。

【0007】分散共有メモリの従来技術の例としては、 以下のIvyシステム(米・エール大学)、及びDAS Hシステム (米·スタンフォード大学) を挙げることが できる。

【0008】「vyシステムでは、各ページに所有者 (オーナ)が存在し、所有者である計算機が、そのペー ジの複製を保持する計算機の名称を管理する。また所有 者のみがそのページへ書き込みを行なうことを許されて いる。ある計算機で読み出しフォールトが発生した時に は、所有者からページの複製が送られる。また、書き込 みフォールトが発生した時には、書き込みフォールトを 発生した計算機が新しい所有者となり、他の計算機上に 存在するページの複製は無効化される。

【0009】DASHシステムでは、16バイトのデー タを単位として、Ivyシステムと同様な制御を行なっ

【0010】これらの従来技術の詳細については、「分 散オペレーティングシステム UNIXの次にくるも の、前川守・所真理雄・清水謙多郎編、共立出版、19 91」の124-141頁に示されている。

[0011]

【発明が解決しようとする課題】分散共有メモリではメ モリ内容の一貫性を保つためにネットワークで接続され た計算機間でメモリ内容の交換が行なわれる。この時、 従来の分散共有メモリ管理方式で課題となるのはデータ 転送サイズとデータ転送タイミングである。

【0012】Ivyシステムについては以下の様な課題 がある。第1にデータ転送サイズに関して、メモリ内容 交換のために計算機間を流れるデータ転送サイズがペー ジであるため、ページサイズ (例えば、4キロバイト) と比較して小さいデータ(例えば、8バイト)を計算機 間で共有している場合、計算機間を流れるデータ転送量 に無駄が発生する。このため、実質的なネットワーク資 源の利用率が下がるという課題がある。

【0013】また、計算機Aと計算機Bの各計算機でア メモリでは、メモリが物理的に分散しているので、各計 50 クセス頻度が高い2つの異なるデータが同一ページ上に

存在する場合に、計算機Aと計算機Bが交互に同じペー ジに対するメモリ書き込みを行なうと、ページが計算機 Aと計算機Bの間を移動する。このため、各計算機がメ モリアクセスを行なう度に、ネットワークを介した計算 機間でのページ転送が発生し、メモリアクセスの性能が 下がるという課題がある。

【0014】第2にデータ転送のタイミングに関して、 データ転送はメモリへの読み出しや書き込み時に自計算 機内に共有データの存在するページがない時にページフ ォルトを発生して行なっていた。

【0015】そのため計算機Aと計算機Bが同じ共有デ ータに連続して書き込みを行うと、最悪の場合、各計算 機がメモリ書き込みを行なう度にページが計算機間を移 動する。ネットワークを介して計算機間の転送を行なう コストは、自分の計算機内のメモリアクセス速度と比較 して大きいため、共有データへのメモリアクセスの性能 が下がるという課題がある。

【0016】一方DASHシステムは、【vyシステム の第1の課題の解決を狙ったシステムである。即ち、ペ 駄なデータ転送を無くすために共有の単位を小さくし た。その結果、無駄なデータ転送はなくなったが、メモ リの広範囲に対してアクセスを行なうとアクセスフォー ルトが頻繁に発生することとなった。アクセスフォール トが頻繁に発生すると、ネットワークを介して行なう計 算機間でのデータ転送時間が顕著になる。DASHシス テムでは、これに対して小さいデータの転送時間を短く することを目的として、特殊化した専用ネットワークを 提案している。しかし、この専用ネットワークは汎用ネ いという問題がある。

【0017】更にIvyシステムの第2の課題である、 複数計算機が同じ共有データに対して連続してアクセス した場合の性能低下については、DASHシステムに於 いても発生し解決されていない。

【0018】上記課題に起因して、従来の分散共有メモ リ方式を、典型的な並列処理手法である領域分割型並列 処理に適用した場合、ネットワークを介した通信が頻繁 に発生し、並列化による処理の高速化率で良好な値を得 ることができない。更にポインタ変数を要素とするデー 40 タ構造体を複数計算機間で共有する場合等、共有の対象 となるデータがメモリ上で散在して格納されることがあ り、この様な場合にもネットワークを介した通信が頻繁 に発生する。

【0019】本発明の目的は、上記課題を解決し、ネッ トワーク資源の有効活用、及びアクセス性能の高い分散 共有メモリ方式を提供することにある。

[0020]

【課題を解決するための手段】先ず、第1の課題を解決

リへの写像を設定可能とし、設定した共有単位を記憶し ておくための共有データ管理テーブルを有し、その共有 データ管理テーブルを管理するための共有データ管理手 段を設ける。

【0021】具体的には、アプリケーションが2次元配 列の様なデータを2分割し、分割した境界部分のデータ を共有する場合には、アプリケーションからその境界部 分のデータを共有単位として設定する。共有単位は、メ モリ連続領域、メモリ不連続領域(データサイズ一定、 データの間隔一定)、またはそれらの組合わせによって 10 指定する。

【0022】次に第2の課題を解決するために、複数の 計算機上の共有データの一貫性を保証するタイミングを アプリケーションが仮想的な共有空間からの(1)最新 データの獲得指示、共有空間への(2)最新データの反 映指示という2つの情報に基づいて決定し、一貫性を保 証する単位として設定された共有単位を使用する。

【0023】具体的には、全ての計算機に共有データを 持たせ、共有データを変更する計算機に於ける(2)最 ージ単位でメモリ内容を共有しているために発生する無 20 新データの反映指示のタイミングで全ての共有データの 更新を行なう方法、または一つの計算機に共有データを 持たせて、共有データを獲得しようとした計算機に於け る(1)最新データ獲得指示のタイミングで共有データ を保持している計算機から共有データをネットワークを 介して獲得する方法、更に、共有データの信頼性を髙め るために、これら2つの方法を組み合わせて一つ以上の 計算機で共有データを保持し、危険を分散してもよい。 [0024]

【作用】アプリケーション実行時に、予め共有単位を設 ットワーク・アーキテクチャとは異なるためコストが高 30 定することによって無駄なデータ転送を防ぎ、ネットワ ーク資源を有効に活用することができる。また、物理的 に分散しているデータの一貫性をアプリケーションが必 要な時のみ保証することによって、ネットワークを介し た計算機間の転送を最小現に抑さえてネットワーク資源 を有効活用できる。その結果、共有データへのアクセス 性能を向上できる。

[0025]

【実施例】図1は、本発明に於けるネットワーク計算機 システム100の一実施例を示すブロック図である。 【0026】本図に於いて、ネットワーク計算機システ ム100は、複数の計算機101をネットワーク102 で接続して構成される。計算機101に於いて、103 は計算機を構成する各ブロック間のデータ伝送路である システム・バス、104はプログラムを実行するプロセ ッサ、105はプログラムやデータを格納する磁気ディ スクなどの補助記憶装置、106はプログラム実行中に 該プログラムやデータを格納するためのメインメモリ、 107はネットワーク102との入出力を制御するため のネットワーク・インタフェースである。本発明による するために、アプリケーションで共有するデータとメモ 50 共有データ管理方式は、例えば計算機101(1)上の

アプリケーションと計算機 101 (2) 上のアプリケーションが並列実行する時に、データを共有する際に適用される。

【0027】図2は、領域分割型並列処理に対して、本発明による分散共有メモリを適用する場合の一実施例を示す図である。

【0028】 ここで領域分割型並列処理とは、図2

(a) に示す様なデータ配列を、図2(c)、(d) に示す様に分割して、それぞれを別々の計算機上で並列に処理する形式の並列処理のことである。流体解析問題や構造解析問題等、多くの科学技術計算には、領域分割型並列処理を適用可能である。

【0029】領域分割型並列処理の一例として、二次元 熱拡散解析問題の一解法を図2を用いて説明する。本解 析手法では、解析対象となる領域を図2(a)に示す様 なn×n二次元メッシュ状に区切り、配列データ202 としてメインメモリ106上に格納して、プロセッサ1 04が演算処理を行なう。との際、配列データ202の 各要素には、各要素の温度値を格納する。演算処理は、 図2(a)の二次元配列の全要素に対して、各要素の近 20 傍要素を用いた計算を行ない、それを各要素の一定時間 後の値として設定する処理を、予め定められた終了条件 が満たされる迄、繰り返し行なう形態をとる。ことで各 要素の近傍要素を用いた計算とは、例えば図2に示した 様に、配列要素(m, m)の新たな値を計算する際に、 その4近傍点、即ち(m, m-1), (m+1, m), (m, m+1), (m-1, m) と、(m, m) 自体の 値を用いて計算することである。本計算の一例は、配列 要素(m, m)の値に対して、各近傍点の値と(m, m)との値の差異を先ず求め、それに熱伝導率に該当す る係数を乗じた上で、(m,m)の値に加算するもので

【0030】図2(c)、(d)に、本解析手法を二台の計算機上で並列に処理する場合の領域分割を示す。上記の様に本解析では各配列要素の演算のために近傍点のみを用いるため、x=0からx=(n/2)-2迄の列202(1)、及びx=(n/2)+1からx=(n-1)迄の列202(2)に関しては、各領域の演算を担当する計算機のみが読み書きできれば良く、各計算機のローカルメモリ106上に格納されていれば良い。それ 40に対して、x=(n/2)-1からx=(n/2)までの列203(1)及び(2)は、両計算機から読み書きできる必要があり、共有メモリ領域内に格納される必要がある。

【0031】尚、上記の様な解析問題における典型的な問題規模、即ち図2(a)の配列の要素数は、数百行×数百列から数千行×数千列程度のオーダである。

【0032】以下に説明する様に、本発明の分散共有メモリ方式では、計算機間でのデータ交換を、上記の様な領域分割型並列処理に対しても効率良く行なえる方式を 50

提供する。

【0033】図3は、同一のアプリケーションを実行する複数のプロセス間に於いてデータを共有する際の共有データ管理方式の一実施例を示すブロック図である。

【0034】本図に於ては、計算機101(1)上のアプリケーション201(1)と、計算機101(2)上のアプリケーション201(2)とがデータを共有している。ネットワーク計算機システム100を構成する各計算機101は物理的に共有したメモリを持っていないために、物理的に分散した共有データ203(1)と203(2)との一貫性をハードウェア的、ソフトウェア的、またはそれらの組み合わせによる手段で保つ必要がある。この一貫性制御によって、計算機101(1)上のアプリケーション201(1)と、計算機101(2)上のアプリケーション201(2)とが、あたかかってのデュタを共有している様に見ばることがある。

(2)上のアプリケーション201(2)とが、あたかも一つのデータを共有している様に見せることができる。

【0035】本実施例では、共有データの一貫性を保つ 仮想的な空間を各計算機上に存在する共有データ管理システム204によって提供する。アプリケーション201が共有データに対してRead/Writeを行う時には、共有データ管理システム204によって一貫性が 保証された仮想的な空間との間で行なう。本実施例では 具体的には、共有データ複製領域205に格納されたデータを読み書きして行なう。

【0036】本実施例に於ては、全ての計算機101の 共有データ管理システム204には、アプリケーション 201で使用する共有データ203の複製205が存在 する。この複製205は、アプリケーションが共有デー タを使用することを宣言した時に生成される。これはア プリケーション201から共有データ203を獲得する 要求がきた時の処理遅延を最小限にするためである。共 有データ管理システム204では、物理的に分散してい る共有データの複製205に対して一貫性を保証する。 即ち、共有データ管理システムは、ある計算機で共有データの複製を変更した場合には、共有データの複製20 5を保持する全ての計算機101に対して変更を伝達する。

【0037】また、共有データ管理システム204の必要とするメモリ量を節約するために、全ての計算機に共有データの複製を持たずに、アプリケーション201が最新の共有データ反映の指示を行った時に、その指示を行った計算機上に複製を作成する方式をとっても良い。同時に、共有データの複製205を保持する計算機の識別子を他の計算機に通知する。共有データの複製は、ネットワーク計算機システム内の一台、または一台以上の計算機が保持していても良い。

[0038]図4は、本発明による共有データ管理方式の一実施例を示すブロック図である。

50 【0039】共有データ管理システム204は、共有デ

い配列を、行方向、及び列方向に分割して、より多数の 計算機に割り当てて並列処理を行なうことが想定される

が、本図を用いて説明する内容を直接適用することが可

【0047】配列の各要素は8パイト長の倍精度実数と する。分割した境界部分の1列を共有データ番号「0」 を持つ共有データ501、共有データ番号「1」を持つ 共有データ502として宣言する。511は、6行×3 列の部分配列のメインメモリ上の配置を示している。5 11が示す様に共有データ501はメインメモリ上では 不連続領域として配置されている。

【0048】一方、本発明に於て共有データを宣言した 時に作成される共有データ複製のメインメモリ上の配置 の一実施例は、512に示す様に連続領域になってい る。511に於ける共有データの配置と512に於ける 共有データ複製との配置の対応を共有データ管理テーブ ル405に於いて管理している。領域511と512に 格納されたデータの対応付けは、共有データ番号をキー として行っている。との対応はアプリケーションが51 1に於ける共有データを使用すると宣言した時に共有デ ータ管理テーブル405内に自動的に作成する。これに よって、不連続な共有データを一つの識別子 (共有デー タ番号)で指定でき、かつ不連続なデータを一つにまと めることによって無駄なメモリ領域を必要としない。

【0049】図6は、本発明に於ける共有データ管理テ ーブル405の一実施例を示し、特に領域分割型並列処 理に適したテーブル構造を示す図である。

【0050】共有データ管理テーブル405は、共有デ ータ番号エントリ601、共有データを管理している計 2、共有データの開始アドレスを示す共有データアドレ ス・エントリ603、共有データの複製の開始アドレス を示す共有データ複製アドレス・エントリ604、共有 データの大きさを示す共有データサイズ・エントリ60 5、共有データを保持している計算機リスト・エントリ 609からなる。

【0051】また、アプリケーションが使用する共有デ ータが連続領域か否かを示す分割フラグ・エントリ60 6、幾つの分割されたデータから共有データが構成され 実行される。即ち、各ソフトウェア処理の内容を記述し 40・ているかを示す共有データ要素数エントリ607、分割 されたデータがどのくらいの間隔で並んでいるかを示す 共有データオフセット・エントリ608を保持する。こ れによって、アプリケーションは連続したメモリ領域の 共有データだけでなく、一定サイズのデータが一定間隔 で並んだメモリ領域を共有データとして宣言することが 可能である。

【0052】更に計算機リスト・エントリ609によっ て、共有データ番号で示される共有データを保持する全 ての計算機を特定することができる。共有データ変更を 並列処理することを例に採る。実際にはより要素数の多 50 他の計算機に通知するために、計算機リスト・エントリ

ータ番号識別部401、共有データ番号付加部402、 パケット送受信部403、共有データ領域管理部404 から構成される。また、補助記憶装置105には、共有 データ管理テーブル405を持つ。共有データ管理テー ブル405は、予めメインメモリ106に展開しておく ことによって、その参照、更新処理を高速化することが できる。共有データ管理テーブル405の詳細について は後述する。

【0040】共有データ番号識別部401は、パケット 送受信部403から送られてくるパケットの共有データ 10 番号を識別する。共有データ番号に対応するメモリ領域 を共有データ領域管理部404を利用して調べ、対応す るメモリ領域に対してデータを書き込む処理を行なう。 【0041】共有データ番号付加部402は、共有デー タ領域管理部404から共有データ番号とそれに対応す るメモリ領域を受け取り、メモリ領域を読み込んで他の 計算機に共有データの内容を伝達するパケットの生成を 行なう。

【0042】パケット送受信部403は、ネットワーク ・インタフェース107から送られてくるパケットのコ 20 マンドを解析し、そのパケットを処理するブロックに振 り分ける。また、共有データ番号付加部402で作成し たパケットを他の計算機に伝達するためにネットワーク ・インタフェース107を起動する処理を行なう。

【0043】共有データ領域管理部404は、共有デー タ管理テーブル405の管理と共有データ管理システム 204のブロックを制御する処理を行なう。また、アプ リケーション201の共有データに対する処理依頼を受 け取り、共有データ管理テーブル405に新しいエント リを追加したり、削除を行なう。更に、共有データの内 30 算機かどうかを示す管理ノードフラグ・エントリ60 容を他の計算機に伝達する様に共有データ番号付加部4 02やパケット送受信部405を制御する。逆に共有デ ータの内容を他の計算機から受け取れる様に共有データ 番号識別部401やパケット送受信部403を制御す る。

【0044】図中401から404に於いて行なわれる 各処理は、ソフトウェア的、ハードウェア的、またはそ の組み合わせによって行なわれるものである。ソフトウ ェア的に行なわれる部分の処理に関しては、以下の様に たプログラムは補助記憶装置105に格納されており、 システム・バス103に接続されたメインメモリ106 に展開した上で、プロセッサ104によって実行され

【0045】図5は領域分割型並列処理を行う際に、配 列データを分割した時の共有データのメモリ配置を示す 一実施例である。

【0046】本図に於ては簡単化のために、6行×6列 の配列を列方向に2分割して、2台の計算機を利用して

609を利用してもよい。利用しない場合には、ネットワークに接続されている全ての計算機に通信を行なうブロードキャスト機能を使えばよい。但し、ここで要求されるブロードキャスト機能は、パケット消失が発生しない、各計算機で受信するパケットの順番が変わらないという信頼性を持つ必要がある。

【0053】共有データの複製を全ての計算機が保持しない場合には、共有データの複製を保持している計算機の識別子を格納する項目を必要とする。

【0054】図7は、複数計算期間で、ポインタ変数を 10 含むデータ構造体を共有する際の共有データのメモリ配置を示す一実施例である。

【0055】図7(a)にC言語でのデータ構造体の宣言の一例を示す。本例に於ては三番目の要素cが正数型のポインタ変数となっている。以下、本構造体を共有する場合を例に、本発明による一実施例を示す。

【0056】図7(a)に示したデータ構造体を共有す る場合、メモリ上では図7(b)の511に示す様に配 置される。本配置に於て、要素cの領域701に格納さ れるのはメモリ上のアドレス値であり、これによりポイ ンタを介してデータ領域702を指し示す。データ構造 体を複数計算機間で共有する場合、共有したいデータは 要素a, b, d、及び領域702に格納されたデータで あり、要素cに格納されたアドレス値自体は共有する必 要がない。これは各計算機が独立したメインメモリ10 6を管理しており、各計算機上での領域511内の共有 データ格納アドレスは必ずしも一致しないためである。 【0057】一方、本発明に於て共有データを宣言した 時に作成される共有データ複製のメインメモリ上の配置 の一実施例を512に示す。512では、511で要素 30 cを格納していた領域701に該当する703の領域に は、当該データ格納領域の開始位置迄のオフセット値7 04を格納する。またオフセット値704で指定される データ格納領域の先頭705には、データ長706を格 納し、それに連続してデータ7.02を格納する。これに より、ポインタ変数を要素とするデータ構造体を複数計 算機間で共有する場合にも、共有の対象となるデータは メモリ上で連続した領域に格納することができる。

【0058】511に於ける共有データの配置と512 って、一貫性保証処に於ける共有データ複製との配置の対応を共有データ管 40 ークにデータを送出 クの利用効率を向」 512に格納されたデータの対応付けは、対応付けは共 有データ番号をキーとして行っている。この対応は、左 記に図5で示したのと同様に、アブリケーションが51 1に於ける共有データを使用すると宣言した時に共有データ管理テーブル405内に自動的に作成する。これに よって、不連続な共有データを一つの識別子(共有デー なおって、不連続な共有データを一つの識別子(共有デー なお、例えば構造に でま、複数計算機間で共有する場合にネットワークを介した通信の頻繁を減らすことができる。 「の059】図8は、本発明に於ける共有データ管理テ 50 に登録すれば良い。

ーブル405の他の実施例を示し、特にデータ構造体の 共有、及び階層関係を持つ共有データの管理について示 す図である。

【0060】本実施例に於ては、図6に示した共有データ管理テーブル405に対して、610の構造体定義エントリ、及び611の構造体サイズを示すエントリを設けている。共有データ番号601に対応する共有データがデータ構造体の場合、構造体定義エントリ610にはデータ構造体の定義を格納し、その共有データ複製領域512上でのデータ長を611に格納する。本図に於ては、共有データ番号「11」の共有データが、データ構造体であることを示している。

【0061】共有データ管理テーブル405の構造体定義エントリ610に格納する構造体定義テーブルの一実施例を図9(a)に示す。構造体定義テーブル801は、当該データ構造体の要素の型情報を格納するエントリ802、当該要素のサイズを格納するエントリ803、当該要素の当該データ構造体内での開始位置を格納するエントリ804、当該要素がポインタ型の場合に、20 それが指し示すデータのサイズを格納するデータサイズ・エントリ805により構成される。

【0062】更に図8に於て、階層要素フラグ・エントリ612、及び階層要素共有データ番号エントリ613を設けることにより、複数の共有データに対して階層関係を定義しておき、共有データの一貫性保証処理のための獲得処理等を下位階層として定義されたデータを含めて、一纏めで実行することが可能となる。例えば図8に於ては、共有データ番号「5」の共有データの下位階層データとして、共有データ番号「6」の共有データが定義されており、更に共有データ番号「6」の下位階層には何も定義されていない。この場合、例えば共有データ番号「5」の一貫性保証処理を指示すると、共有データ番号「5」の一貫性保証処理を指示すると、共有データ番号「6」の一貫性保証処理を指示した場合には、その共有データに対してのみ、同処理を実行する。

【0063】尚、階層関係にある共有データは、共有データ複製領域512上で連続して配置しておくととによって、一貫性保証処理を実行する際に一括してネットワークにデータを送出することが可能となり、ネットワークの利用効率を向上することができる。

【0064】また、図7のポインタ変数を含むデータ構造体を階層構造として管理することもできる。即ち、データ構造体の要素 a からd の本体部分を一つの共有単位として扱い、その下位階層の共有単位として、要素 c が指し示すデータ部分702を定義すれば良い。また複数のポインタ変数がデータ構造体内に定義されている場合には、例えば構造体定義に表れる順番で、下位階層の共有データ番号を階層要素共有データ番号エントリ613

【0065】ポインタ変数を含むデータ構造体を階層構 造として管理する別の実施例を、図9(b)に示す。構 造体定義テーブル802は、801と同等の803から 805のエントリと、当該要素がポインタ型の場合に、 それが指し示すデータの共有データ番号を格納するエン トリ806により構成される。

【0066】図10は、本発明による共有データ管理シ ステム204が使用するパケット構造の一実施例を示す 図である。

【0067】パケット901は、パケットヘッダ902 10 とデータ903より構成される。パケットヘッダ902 は、送信先計算機904、送信元計算機905、共有デ ータ番号906、共有データ管理コマンド907より構 成される。例えば、共有データ番号12を持つ共有デー タの変更を計算機1が計算機2に通知する場合には、送 信先計算機904に「2」、送信元計算機905に1、 共有データ番号906に12、共有データ管理コマンド 907に「共有データ変更通知」を示す識別子を、デー タ903に変更された共有データの内容を格納して、共 有データを保持する計算機もしくは全ての計算機にパケ 20 ットを送信する。

【0068】図11は、本発明による共有データ管理方 式を適用するためにアプリケーション201に提供する 共有データへのアクセス関数の一実施例を示す表であ る。

【0069】本実施例の「dsm_」で始まる文字列 は、共有データ管理システムを使用するためにアプリケ ーションが呼び出すオペレーティング・システムの関数 の名称である。アプリケーションが共有データにアクセ スするためには初期化処理、一貫性保証処理、終了処理 を行なう。

【0070】先ず、1001及び1002の初期化処理 dsm_open、dsm_open2に於いて、アブ リケーションが使用する共有単位を共有データ管理シス テムに宣言する。具体的にはあるメモリ領域に、共有デ ータ番号を対応付ける。共有データ管理システムでは、 共有単位を管理するために必要な管理情報のエントリを 確保する。1001のdsm_openは、連続したメ モリ領域を一つの共有単位として宣言する。1002の 定の間隔で並んでいるメモリ領域を一つの共有単位とし て宣言する。

【0071】次に1003及び1004の一貫性保証処 理dsm_acquire、dsm_releaseに 於いて、アプリケーションが共有単位として宣言したメ モリ領域に対してRead/Write操作を行なう時 は、一連のRead/Write操作を1003のds m_acquire & 1004 Ods m_releas eとで囲むことによって、共有データ管理システムは共 有単位の一貫性を保証する。

【0072】最後にアプリケーションが共有データ(共 有単位)を必要としなくなった場合には、1005の終 了処理dsm_closeを共有データ管理システムに 発行する。との発行によって、初期化処理で確保した共 有データ管理システム内の管理情報の領域を解放すると とができる。

14

【0073】尚、初期化処理、一貫性保証処理、終了処 理時に共有データ管理システム内で行なわれる処理内容 の詳細は後述する。

【0074】図12は、本発明による分散共有メモリを 利用した領域分割型並列処理を行う際のアプリケーショ ンのメイン処理の一実施例を示すフローチャートであ る。

【0075】ここで各計算機上のアプリケーションは、 図2及び図5に示した配列データの各要素に対して、先 に図2(b)を用いて説明した様な上下左右の隣接要素 と自要素の値を用いた演算処理を行う。

【0076】先ずステップ1101で、補助記憶装置な どに格納された配列データからアプリケーション201 (1)に必要な配列データをメインメモリ106に読み 込む。ステップ1102では、アプリケーションで使用 する共有データの宣言を行う。具体的には、部分配列5 01のメモリ領域を共有データ番号「0」、部分配列5 02のメモリ領域を共有データ番号「1」として宣言す る。図中では、それぞれの宣言を(open 0)、 (open 1)と略記したが、これはそれぞれ100 1のルーチンを用いて行う。ステップ1103では、ア プリケーション201(1)が取り扱う部分配列の中 で、共有データ番号「0」を持つ共有データを仮想的な

30 共有空間に反映する操作をルーチン1004を用いて実

【0077】次のステップ1104からステップ110

行する。図中では、(rel 0)と略記した。

8までが、アプリケーションのメインループに対応す る。ステップ1104で他のアプリケーションと同期を 取る。ステップ1105では、仮想的な共有空間から最 新データを獲得するための操作を実行する。ことでは、 移動元を共有データ「1」、移動先を同じ共有データ 「1」として1003のdsm_acquire処理を 実行する。図中では、この操作を(acq 1)と略記 dsm_open2は、一定のサイズを持つデータが一 40 した。ステップ1106では、部分配列の全ての要素に ついて上下左右の隣接要素と自要素を用いた演算処理を 実行する。ステップ1107では、ステップ1106の 結果を仮想的な共有空間に反映する操作をステップ 1 1 03と同様に実行する。ステップ1108では、計算が 終了したが否かを判定し、終了していない場合にはステ ップ1104に戻り、ステップ1108迄の処理を繰り 返し行う。終了した場合にはステップ1109に進む。 【0078】ステップ1109では共有データの解放処・ 理を行う。ここでは、共有データ番号「0」を持つ共有 50 データ、共有データ番号「1」を持つ共有データの解放

処理を、ルーチン1005を用いて行う。図中では、それぞれ(close 0)、(close 1)と略記 した。

【0079】アプリケーション201 (2) についても、ステップ1101からステップ1109と同様な処理を実行する。但し、担当する部分配列が異なるため、ステップ1114、ステップ1116では、それらに対応するアプリケーション201

(1) に於ける処理ステップとは異なる共有データに対して操作を行う。

【0080】図13は、図11で示した共有データの初期化処理を行なう際、共有データ管理システムが行なう処理の一実施例を示すフローチャートである。

【0081】ブロック1201で囲まれた処理ステップは、共有データの使用を宣言したアプリケーションを実行している計算機101で行なわれる処理内容を、ブロック1202で囲まれた処理ステップは、共有データ番号で決定される共有データを管理する計算機で行なわれる処理内容を示している。

【0082】先ずステップ1203で、アブリケーショ 20 ンが共有データ領域管理部404に共有データ番号と共 有データのメモリ領域を指定して共有データの使用を宣 言するために1001のdsm_openルーチンを起 動する。処理ステップ1204では、指定された共有デ ータ番号に基づき、共有データを管理する計算機を決定 する。例えば、ネットワーク計算機システムを構成する 計算機に予め一意な番号を割り当てておき、共有データ 番号をネットワーク計算機システムを構成する計算機の 総数で割った余りが、ある予め決定された番号と一致し た計算機を管理計算機として決定してもよい。ステップ 30 1205では、共有データ領域管理部が決定した共有デ ータの管理計算機に対して共有データを使用することを 通知する。 共有データを管理する計算機では、ステッ プ1206に於いて、宣言された共有データがすでに使 用されているか否かを確認する。使用されていない場合 には、ステップ1210で、管理計算機の共有データ管 理テーブル405に新しいエントリを作成する。また、 共有データ保持計算機リストの初期設定を行なう。使用 されている場合には、ステップ1207に於いて、共有 データを使用することを宣言した計算機を609の共有 40 データ保持計算機リストに追加し、ステップ1208で 共有データ保持計算機リストに登録されている計算機に 対して共有データ保持計算機リストが変更されたことを 通知する。

【0083】共有データの使用を宣言した計算機では、 共有データが宣言されていた場合には、ステップ120 9で共有データ保持計算機リストに基づき最新の共有データの内容を獲得して、それを共有データの複製とする。宣言されていなかった場合には、ステップ1211 で共有データの複製のメモリ領域を確保する。 【0084】ステップ1212では、共有データ管理テーブル内に新しいエントリを作成し、共有データアドレスや共有データ複製アドレスなどの初期設定を行なう。 【0085】図14は、図11で示した共有データの一貫性保証処理を行なう際、共有データ管理システムが行なう処理の一実施例を示すフローチャートである。 【0086】ブロック1301で囲まれた処理ステップ

(0086) ブロック1301で囲まれた処理ステップは、最新の共有データを獲得するために1003のdsm_acquireを発行した計算機で行なわれる処理10 内容を示している。

【0087】先ずステップ1302ではアブリケーション内の共有データに最新の共有データを獲得するために、獲得する共有データ番号(移動元)と獲得した共有データを置くメモリ領域を示す共有データ番号(移動先)を指定して共有データ領域管理部404にdsm_acquireを発行する。

【0088】ステップ1303で獲得したい共有データ番号(移動元)に対応する共有データ複製アドレス、共有データサイズなどを共有データ管理テーブル405から共有データ番号をキーとして検索する。

【0089】次にステップ1303と同様にステップ1304では、移動先を示す共有データ番号に基づいて、 共有データ番号に対応する共有データアドレス、及び共 有データサイズを調べる。

【0090】ステップ1305では、移動元である共有 データ複製205のメモリ領域512の内容を移動先の 共有データのメモリ領域511にコピーを行なう。

【0091】ステップ1305でコピーを行う際には、共有データ管理テーブル405の分割フラグ606に「1」が格納されている場合、図5に示した領域512の格納形式から領域511の格納形式への変換を行う。これは、データをコピーする際に、各要素毎に共有データオフセット値608分のアドレス間隔でコピーを行うことによって実施する。また同様に、共有データ管理テーブル405の構造体定義エントリ610に構造体定義が、また階層要素フラグ612に「1」が格納されている場合にも、格納形式の変換を行いながら、領域512から511へのデータコピーを行う。

【0092】図15は、図11で示した共有データの一 貫性保証処理を行なう際、共有データ管理システムが行 なう処理の一実施例を示すフローチャートである。

【0093】ブロック1401で囲まれた処理ステップは、アプリケーションの共有データを共有データ管理システムに反映するために1004のdsm_releaseを発行した計算機で行なわれる処理内容を、ブロック1402で囲まれた処理ステップは、共有データの反映があった共有データを保持している全ての計算機で行なわれる処理内容を示している。

【0094】先ずステップ1403ではアプリケーショ 50 ン内の共有データ内容を共有データ管理システムに反映

させるために、共有データ番号を指定して共有データ領 域管理部に1004のdsm_releaseを発行す

【0095】ステップ1404では、指定された共有デ ータ番号に対応するメモリ領域を共有データ管理テーブ ルを共有データ番号をキーとして検索する。更に、共有 データ番号付加部が、対応するメモリ領域の内容を読み だし、指定された共有データを保持する全ての計算機に 対して変更を伝達するためのパケットを作成する。

リ領域511の内容を共有データ複製205のメモリ領 域512にコピーする。この際、図14のステップ13 05で行ったコピー処理とは逆方向に処理を実施する。 即ち、図5及び図7に示した領域511の格納形式から 領域512の格納形式への変換を行いながら、データコ ピーを行う。

【0097】ステップ1406では、パケット送受信部 が共有データ管理テーブル内の共有データ保持計算機リ ストに基づいて、共有データ番号付加部が作成したパケ ットを送信する。

【0098】共有データを保持している計算機では、ス テップ1407に於いて、ネットワークによって伝達さ れてきた共有データの変更を通知するパケットをパケッ ト送受信部で受信する。更にパケット内容を調べて、共 有データの変更通知であることを知り、パケット番号識 別部にパケットを渡す。

【0099】ステップ1408では、バケット番号識別 部がパケット内の共有データ番号を識別する。更にその 共有データ番号に基づいて共有データ管理テーブルを検 索し、対応する共有メモリ複製アドレス、共有メモリサ イズなどを調べる。

【0100】ステップ1409では、共有データ識別部 がネットワークから到着した共有データ変更通知に基づ いて対応するメモリ領域に対して書き込みを行なう。

【0101】図16は、図11で示した共有データの終 了処理を行なう際、共有データ管理システムが行なう処 理の一実施例を示すフローチャートである。

【0102】ブロック1501で囲まれた処理ステップ は、共有データの解放を要求した計算機で行なわれる処 理内容を、ブロック1502で囲まれた処理ステップ は、共有データ番号で決定される共有データを管理する 計算機で行なわれる処理内容を示している。

【0103】先ず、ステップ1503で、アプリケーシ ョンが共有データ領域管理部に対して共有データ番号を 指定して共有データを解放するために1004のdsm <u>_ r e l e a s eを発行する。処理ステップ l 5 0 4 で</u> は、指定された共有データ番号に基づき、共有データを 管理する計算機を決定する。ステップ 1505では、共 有データ領域管理部が決定した共有データの管理計算機 に対して共有データを解放することを通知する。

【0104】共有データを管理する計算機では、ステッ プ1506に於いて、解放を宣言された共有データに対 して、その共有データ番号に基づいて共有データ管理テ ーブルの共有データ保持計算機リストから、解放を要求 した計算機を削除する。

【0105】ステップ1507に於いて、共有データ管 理テーブルの共有データ保持計算機リストから解放要求 のあった計算機を削除した結果、共有データ保持計算機 リストが空になったか否かを確認する。計算機リストが 【0096】ステップ1404では、共有データのメモ 10 空の場合には、ステップ1508に於いて、共有データ を管理している計算機内の共有データ管理テーブル40 5から共有データのエントリを削除する。計算機リスト が空でない場合には、ステップ1509に於いて共有デ ータ保持計算機リストに登録されている計算機に対して 共有データ保持計算機リストの変更を通知する。

> 【0106】共有データの解放を宣言した計算機では、 ステップ1510で共有データ管理テーブル内から共有 データのエントリを削除し、共有データ複製のために割 り当てられていたメモリ領域を解放する。

20 【0107】以上、本発明の実施例について説明してき たが、最後に、再度図4を用いて、本発明の好適な実施 例における目的、構成、及び効果について簡単にまとめ る。

【0108】ネットワークで接続した複数の計算機で構 成されるネットワーク計算機システムで、アプリケーシ ョンに対してあたかも一つのデータを共有しているかの 様にみせる分散共有メモリを実現するために、アプリケ ーションが使用する共有データに関して、共有するデー タ領域や、共有するデーター貫性保証のタイミング等の 30 共有データに関する情報を得て、ネットワーク間を流れ るデータ転送量や転送回数を減らし、ネットワーク資源 を有効に活用し、共有データへのアクセス性能を向上さ せる。

【0109】本発明の好適な実施例である図4において は、共有データ管理システム204は、共有データ番号 識別部401、共有データ番号付加部402、パケット 送受信部403、共有データ領域管理部404から構成 され、共有データ管理テーブル405を保持する。

【0110】アプリケーション201が共有するデータ (共有単位)とメモリへの写像を共有データ領域管理部 40 404に対して宣言すると、共有データとメモリとの対 応を共有データ管理テーブル405に格納する。共有デ ータの一貫性を保証するために、共有データ変更を指示 した計算機と共有データ変更を受け取る計算機に於い て、次の様な構成を取る。

【0111】共有データの変更を指示した計算機では、 変更した共有データを他の計算機に通知するために共有 データ番号に対応するメモリ領域を調べ、メモリ領域の 内容に共有データ番号を付加して、通知用パケットの作 50 成を行なう共有データ番号付加部402を設ける。

【0112】共有データ変更を受け取る計算機では、ネ ットワークから伝達されてきたパケットの共有データ番 号を識別し、共有データ番号に対応するメモリ領域を共 有データ管理部を利用して調べ、対応するメモリ領域に 対してデータを書き込む処理を行なう共有データ番号識 別部401を設ける。

【0113】また両計算機に於いてパケットの送受信を 行ないネットワーク・インタフェースの制御を行なうパ ケット送受信部403を設ける。

【0114】本発明の好適な実施例によれば、アプリケ 10 ーションが使用する共有データに関する情報を共有デー タ管理システムに通知する手段を設けたことにより、ネ ットワークを流れる無駄なデータ転送量や転送回数が減 り、ネットワーク資源を有効に利用することができると 共に、無駄なデータを転送しないのでネットワークの転 送時間も短くなり共有データへのアクセス性能が向上 し、例えば領域分割型の並列処理に於て、並列化による 髙速化率を向上することができる。

[0115]

【発明の効果】本発明によれば、ネットワークで接続し 20 た複数の計算機システムで構成されるネットワーク計算 機システムに於いて、アプリケーションに対してあたか も一つのデータを共有しているかの様にみせる分散共有 メモリを実現する際に、共有データの一貫性を保証する ために必要なネットワークの転送量や転送回数が減少す るので、ネットワーク資源を有効に活用することができ る。更に、無駄なデータ転送をしないのでネットワーク の転送時間が短くなり、その結果、共有データへのアク セス性能を向上させることができる。

【図面の簡単な説明】

【図1】本発明の一実施例のネットワーク計算機システ ムのブロック図である。

【図2】本発明の適用対象の一例である領域分割型並列 処理の一実施例を示す図である。

【図3】本発明による共有データ保持の一実施例を示す 図である。

【図4】本発明に於ける共有データ管理システムの一実 施例を示すブロック図である。

【図5】本発明による共有データの領域分割型並列処理 への応用を示す一実施例である。

【図6】本発明に於ける共有データ管理テーブルの一実 施例を示す図である。

【図7】本発明による共有データのデータ構造体への応 用を示す一実施例である。

【図8】本発明に於ける共有データ管理テーブルの一実 施例を示す図である。

【図9】本発明に於ける構造体定義テーブルの一実施例 を示す図である。

【図10】本発明に於ける通信バケット構造の一実施例 を示す図である。

【図11】本発明による共有データアクセス関数の一実 施例を示す図である。

【図12】本発明による共有データを利用したアプリケ ーションのメイン処理の一実施例を示すフローチャート である。

【図13】本発明による共有データ使用開始処理の一実 施例を示すフローチャートである。

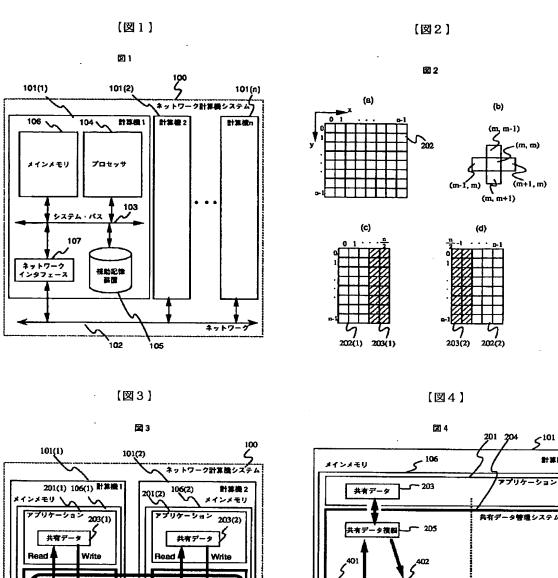
【図14】本発明による共有データ獲得処理の一実施例 を示すフローチャートである。

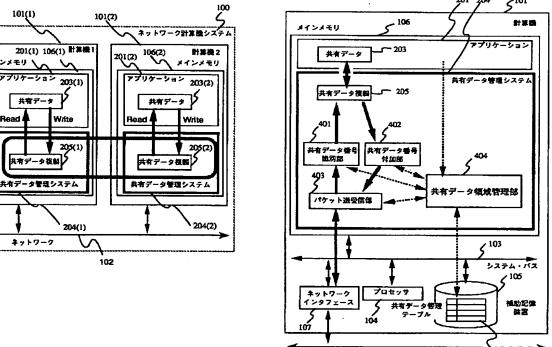
【図15】本発明による共有データ反映処理の一実施例 を示すフローチャートである。

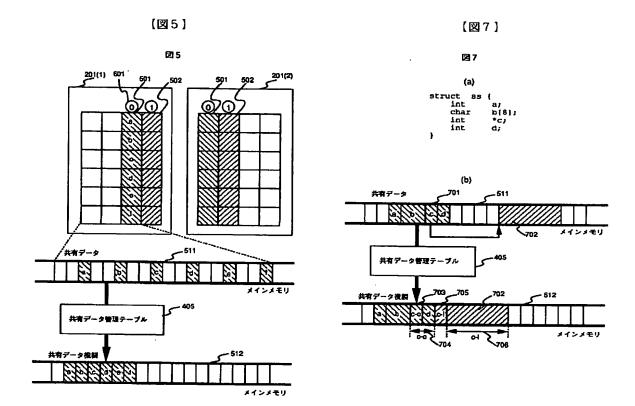
【図16】本発明による共有データ解放処理の一実施例 を示すフローチャートである。

【符号の説明】

100:ネットワーク計算機システム、101:計算 機、102:ネットワーク、103:システム・バス、 104:プロセッサ、105:補助記憶装置、106: メインメモリ、107:ネットワーク・インタフェー ス、201:アプリケーション、202:アプリケーシ ョン内のローカルデータ、203:アプリケーション内 の共有データ、204:共有データ管理システム、20 5:共有データ管理システム内の共有データ複製、40 1:共有データ番号識別部、402:共有データ番号付 加部、403:パケット送受信部、404:共有データ 領域管理部、405:共有データ管理テーブル、50 1:共有データ番号「0」を持つ共有データ、502: 共有データ番号「1」を持つ共有データ、511:共有 データのメインメモリ上での配置、512:共有データ 複製のメインメモリ上での配置、601:共有データ番 30 号、602-613: 共有データ管理テーブルの管理項 目、701-706:データ構造体の共有データ複製領 域上での配置要素、801、802:構造体定義テーブ ル、803-807:構造体定義テーブルの管理項目、 901:通信パケット、902-907:通信パケット 構成要素、1001-1006:共有データのアクセス 関数、1301-1318:共有データを利用した領域 分割型アプリケーションのメイン処理ステップ、120 1:共有データの使用を要求した計算機内での処理ステ ップ、1202:共有データ管理計算機内での処理ステ ップ、1203-1212:共有データ使用を要求した 時の処理ステップ、1301:共有データの獲得処理を 発行した計算機内での処理ステップ、1302-130 5:共有データを獲得する時の処理ステップ、140 1:共有データ反映処理を発行した計算機内での処理ス テップ、1402:データを共有する他の計算機内での 処理ステップ、1403-1410:共有データを反映 する時の処理ステップ、1501:共有データ解放を要 求した計算機内での処理ステップ、1502:共有デー タ管理計算機内での処理ステップ、1503-151 50 0:共有データ解放を要求した時の処理ステップ。







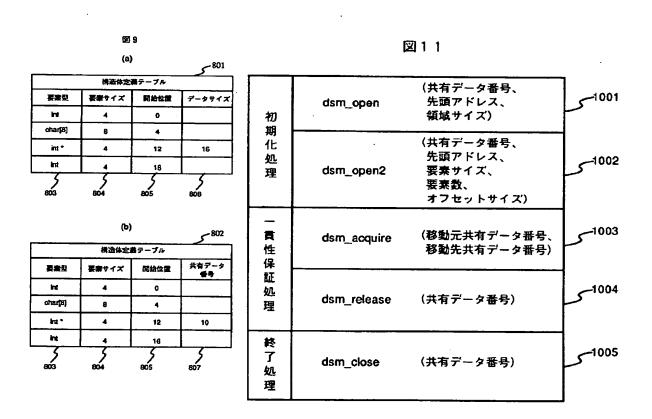
【図6】

	≤ ⁴⁰⁵	•						
			共有5	ータ管理テー	ープル			
共有データ 番号	管理ノード フラグ	共有データ アドレス	共有データ 複数アドレス	共有データ サイズ	分割フラグ	共有データ 要素数	共有データ オフセット	共有データ保持 計算機リスト
1	1	101234	1234	2000	0	_	_	1,2,9
5	0	108758	8758	1024	0	_	_	4,5
11	0	104892	4892	8	1	10	80	7,8,9,10
:	:	•	•	:	:	:	:	•
6	1	107465	7465	В	-1	20	24	1,2,3,4,5,6
	:	:	:	:	:	:	:	•
601	5 602	603	604	605	606	607	508	609

【図8】 【図10】 < 405 共有アータ管理テーブル 共有データ 番号 共有データ保持 計算機リスト 図10 職業要素 フラグ 標遊体 検急体 サイズ 世周安泰 定義 共有データ番号 1 1,2,3 ٥ 0 0 0 ⊠ ∞ 5 4,5 ٥ 6 11 ••• 7,8,8,10 struct as 40 0 ٥ 6 1,2,3,4,5,6 0 0 0 0 送信先 計算機 进信元 計算機 601 602~608 609 610 612 611 613

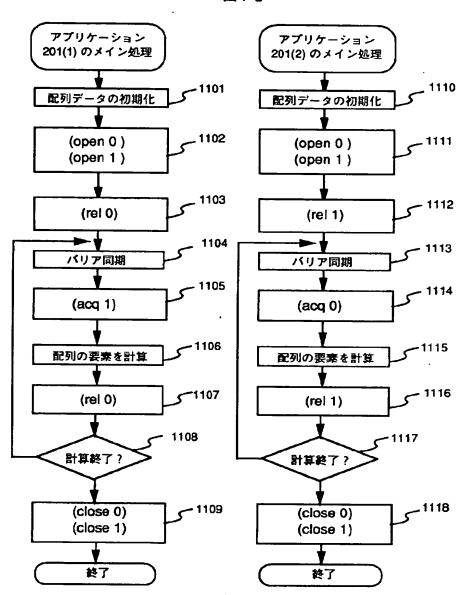
【図9】

【図11】



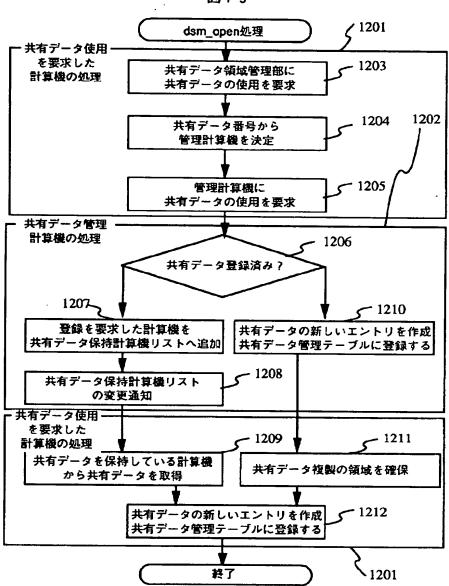
【図12】

図12

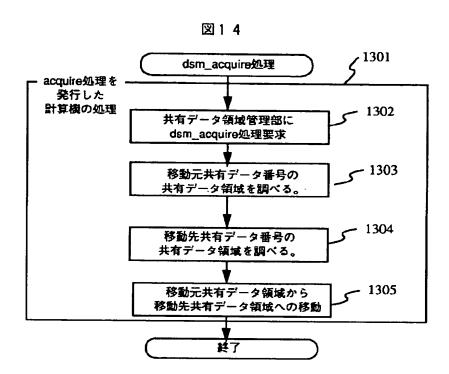


【図13】

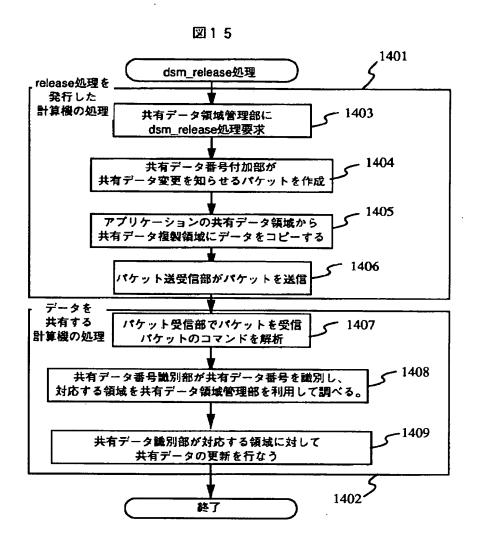
図13



【図14】

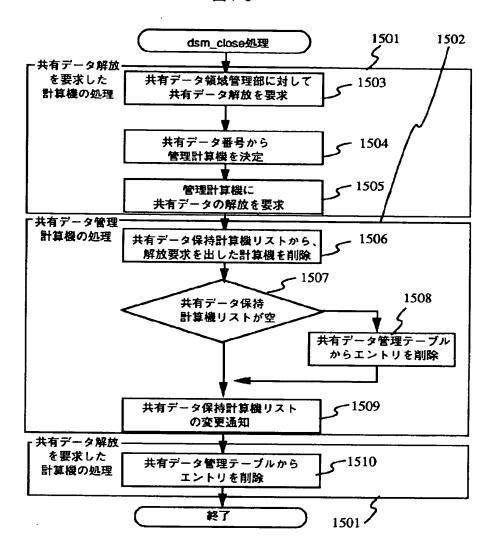


【図15】



【図16】

図16



フロントページの続き

(72)発明者 林 剛久

東京都国分寺市東恋ケ窪1丁目280番地 株式会社日立製作所中央研究所内

(72)発明者 鬼頭 昭

神奈川県横浜市戸塚区戸塚町5030番地 株式会社日立製作所ソフトウェア開発本部内